



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA, INOVAÇÕES E COMUNICAÇÕES
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

ANÁLISE ESPACIAL DE DADOS GEOGRÁFICOS

ANÁLISE DE ÁREAS DE RISCO DE CONTAMINAÇÃO SRAG POR COVID-19
ATRAVÉS DE ESTATÍSTICA DE VARREDURA NA CIDADE DO RECIFE,
PERNAMBUCO, BRASIL

Rayanna Barroso de Oliveira Alves

INPE
São José dos Campos
2021

RESUMO

A identificação de padrões de *clusters* durante a pandemia da COVID-19 tem sido bastante estudada nas grandes cidades para uma gestão epidemiológica e urbana eficaz. Desta forma, o presente trabalho permitiu a utilização de um banco de dados de casos confirmados de Síndrome Respiratória Aguda Grave – SRAG por contaminação do SARS-CoV-2 por bairro no município do Recife. Assim, foi realizada uma análise de conglomerados espaciais para indicação dos bairros com altos índices de risco de contaminação pelo vírus. Para tal, foi utilizada a estatística de varredura Scan (*Scan Statistics*) para analisar e identificar os *clusters* da doença pandêmica. Este trabalho foi capaz de encontrar um aglomerado significativo de contaminação SRAG para o período 2020 a 2021 relativo a cinquenta e um bairros. Os resultados mostram o *cluster* mais provável de SRAG ocorreu na porção leste da cidade, com probabilidade de se expandir para o oeste. Esses resultados fornecem informações que podem ser usadas para a evidência intervenções baseadas para controlar a propagação da SRAG na cidade do Recife.

1. INTRODUÇÃO

O avanço contínuo da contaminação pelo novo coronavírus e a pressão que os gestores estão sofrendo para a criação medidas mais eficazes e identificação dos locais com maior índice de risco está gerando necessidade de identificação mais precisas dos locais com maior índice de risco, a fim de verificar o avanço da pandemia no Brasil.

Segundo Costa et al. (2006), as regiões geográficas ou conglomerados que apresentam risco elevado de ocorrência no que diz respeito a determinado evento são importantes de serem estudadas. Elas podem ser referentes a doenças ou epidemias e é de extrema importância verificar se a distribuição da epidemia é aleatória (hipótese nula – H_0) ou está relacionada a conglomerados de alto risco ou incidência.

No que diz respeito a vigilância de doenças e epidemiologia, essa área utiliza-se bastante de técnicas de detecção de conglomerados (*clusters*) espaciais (KULLDORFF, 2005). Segundo Lawson 1999, o delineamento geográfico dos *clusters* é uma ferramenta importante nos estudos etiológicos, e no alerta precoce de doenças infecciosas.

A compreensão do cenário em que se averiguam os motivos determinantes de intensificação dos agravos à saúde é permitido a partir do geoprocessamento. O cruzamento de informações e correlação com dados epidemiológicos, ambientais e sociais, correlacionado com a aplicação de processos espaciais permitem a análise de causas, consequências, projeções e soluções às respostas de emergência de saúde (BASTOS et. al, 1996).

A fim de detectar grupos ativos e emergentes de determinadas doenças, e identificar os locais que possuem alto índice de casos a estatística de varredura é uma metodologia exploratória preponderante, e contribui para o monitoramento da disseminação do COVID-19 (FERREIRA, et al. 2020).

Assim, o presente trabalho utiliza a estatística de varredura SCAN, a qual segundo Souza et al., 2019 “reconhece o aglomerado espacial que mais provavelmente viole a hipótese nula de não aglomeração; identifica os *clusters* primários e secundários.”, para a geração e identificação de *clusters*, a fim de verificar a contaminação da SRAG por COVID-19 da cidade do Recife.

2. REVISÃO DE LITERATURA

2.1 ANÁLISE ESPACIAL

A área do conhecimento que envolve um conjunto de metodologias e geotecnologias voltadas para aquisição, armazenamento, processamento e representação de dados e informações espaciais é chamada de geoprocessamento. Deste conjunto de ferramentas, podemos destacar os Sistemas de Informações Espaciais (SIG), que dentre outras funções, possibilita o armazenamento e organização de dados espaciais, busca por informações a partir de ferramentas de seleção, análises espaciais e geoestatísticas, construção de cenários e outros (CARDOSO, 2020).

A mensuração de relacionamentos e propriedades através de estudo, exploração e modelagem de um fenômeno geográfico, considerando sua localização espacial, deve ser realizada através de análises espaciais, e seus dados podem ser subdivididos em eventos ou padrões pontuais, superfícies contínuas e áreas com contagem e taxas agregadas (DRUCK et al., 2004).

Segundo Giavoni et al., (2003), “apesar de permitir uma melhor avaliação e compreensão do objeto de estudo, as análises multidimensionais tendem a fragmentá-lo em seus distintos aspectos, perdendo-se a composição global ou unitária do mesmo. Torna-se, portanto, necessário desenvolver um novo tipo de análise que permita uma avaliação integral, na qual as dimensões se tornarão partes constitutivas do corpo do objeto de estudo, podendo este vir a ser representado e avaliado espacialmente, como uma unidade.”

Recente revisão sobre o uso de SIGs e ferramentas de análise espacial em saúde pública aponta para o desenvolvimento de ferramentas que integrem funções de processamento e análise de informações georreferenciadas, cuja implantação dependerá, entretanto, da demanda de métodos de análise espacial, pela comunidade da área da saúde pública, com a integração de metodologias de modelagem estatística e espacial, e sistemas de informações geográficas aplicada em saúde pública (RUSHTON, 2003).

2.2 GEOESTATÍSTICA

A geoestatística, vem a entender, através de análise matemática, das origens e leis naturais de fenômenos e interpreta-os como regionais. Assim, são geradas estimativas das variáveis regionais utilizando informações e relação por conjuntos

discretos de amostras, estabelecendo grau de segurança em revisões e padrões de amostragem por meio da avaliação de erros de estimativa (LANDIM, 2006).

Atualmente, a Geoestatística dedica-se a problemas com comportamento espacial que contenha características intermediárias entre as variáveis verdadeiramente aleatórias e as totalmente determinísticas, ou seja, as variáveis regionalizadas, que são constituídas por um duplo aspecto contraditório. Pela sua característica “aleatória” apresenta irregularidades e variação imprevisível de um ponto para outro e pela sua característica “estrutural” apresenta relações existentes entre os pontos no espaço motivadas pela sua origem (LADIM, 2006).

Para desenvolvimento de análises mais detalhadas, é necessário o conhecimento de características da população, representada pela variável a ser analisada, para a posteriori, realizar uma análise geoestatística. Segundo Sturaro (2015), “outros métodos da estatística univariada ou multivariada, poderão ser requisitados para auxiliar no entendimento da variável, de acordo com os objetivos a serem perseguidos. Além da caracterização das populações, podem também ser utilizadas as análises de correlação e de tendência, visando a compreensão preliminar da variação espacial das variáveis. Estes métodos foram baseados nos textos básicos de estatística ou matemática aplicados à Geologia, com destaque para Kock e Link (1971), Davis (1973), Agterberg (1974) e Landim (1979 e 1988)”.

Em Epidemiologia, a geoestatística tem sido utilizada no estudo da distribuição espacial de diversas doenças. Os métodos geoestatísticos já foram utilizados para analisar a distribuição geográfica de uma epidemia de resfriado comum na França (Carrat & Valleron, 1992), identificar áreas de risco para câncer infantil na região centro-oeste da Inglaterra (Olivier et al, 1992), para modelagem espacial na estimativa dos dados de tuberculose no Brasil (Braga, 1997) e para a caracterização de áreas de risco à saúde (Carvalho, 1997) (MEDRONHO, 1999).

2.3 ESTATÍSTICA DE VARREDURA ESPACIAL

No que diz respeito a análises espacial na área da saúde, inúmeras aplicações e metodologias de análise espacial na saúde coletiva vêm sendo usados principalmente em estudos ecológicos, na detecção de aglomerados espaciais ou espaço-temporais, na avaliação e monitoramento ambiental e aplicados ao planejamento e avaliação de uso de serviços de saúde (ELLIOTT, et al. 2004).

A geoestatística determina se os padrões de espaço-tempo observados da doença são distribuídos aleatoriamente ou exibem agrupamento estatisticamente significativo. Ele utiliza janelas de varredura cilíndricas de diferentes dimensões espaciais e temporais para varrer sistematicamente a área de estudo e o período em busca de incidência excessiva de casos de doença (por exemplo, mais casos observados do que o esperado, dadas as condições iniciais). A versão prospectiva da estatística de varredura desconsiderará os *clusters* que podem ter existido anteriormente e detectará apenas os *clusters* que são uma ameaça ativa e emergente à saúde pública (KULLDORFF, 2001). Isso é diferente da estatística de varredura espaço-temporal retrospectiva, que detecta *clusters* em qualquer ponto durante o período de estudo, independentemente de quando os *clusters* "desaparecem" (FERREIRA et al., 2020).

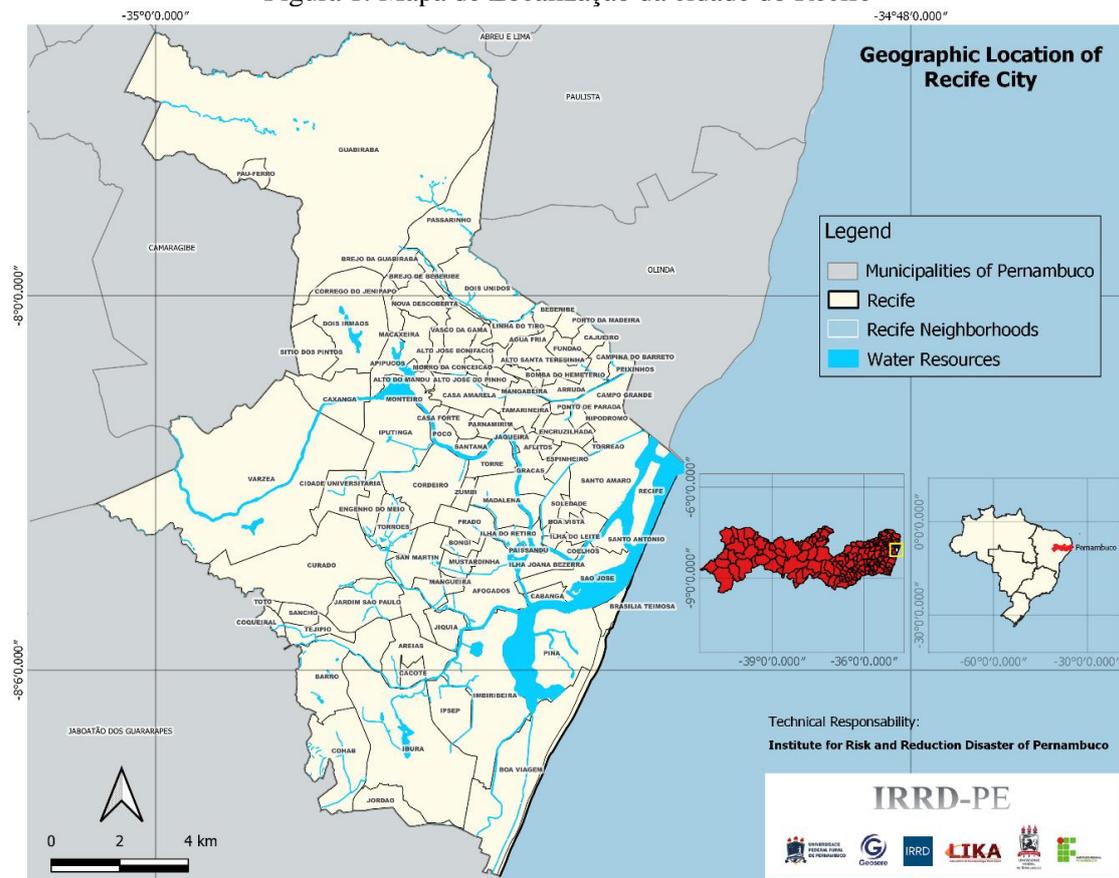
3. METODOLOGIA

3.1 ÁREA DE ESTUDO

A Cidade do Recife está localizada na região Nordeste do Brasil, no litoral do Estado de Pernambuco, sendo considerada sua capital. Possui uma unidade territorial de 218,843 km². É caracterizada pelo bioma Mata Atlântica e possui uma população de 1.537.704 habitantes no censo de 2010, mas população estimada para o ano de 2019 é de 1.645.727 (IBGE, 2021).

O Recife é integrante da Região Metropolitana do Recife (RMR), junto à 14 municípios – Abreu e Lima, Araçoiaba, Cabo de Santo Agostinho, Camaragibe, Goiana, Igarassu, Ilha de Itamaracá, Ipojuca, Itapissuma, Jaboatão dos Guararapes, Moreno, Olinda, Paulista e São Lourenço da Mata – dos quais, faz fronteira com os municípios de Jaboatão dos Guararapes, São Lourenço da Mata, Camaragibe, Paulista e Olinda, nas coordenadas geográficas Latitude: 8°03'14" S e Longitude: 34°52'51"; e é constituído por 94 bairros (Figura 1).

Figura 1: Mapa de Localização da cidade do Recife



Fonte: IRRD, 2020

3.2 DADOS DE CONTAMINAÇÃO SRAG PELA COVID-19

Os dados de casos confirmados da Síndrome Respiratória Aguda Grave - SRAG pela contaminação da COVID-19, foram adquiridos diariamente, desde o início da pandemia no estado – março de 2020, através do Instituto para Redução de Riscos e Desastres de Pernambuco – IRRD-PE e da base de dados da Secretaria Estadual de Saúde de Pernambuco – SES-PE.

Os casos confirmados foram selecionados por bairro de residência (cidade do Recife). A análise temporal foi realizada para o período de um ano: 2020 a 2021.

O número total de casos SRAG na cidade do Recife foi de 10302. A Tabela 1 apresenta os bairros do Recife com os respectivos casos de Síndrome Respiratória.

Tabela 1: Total de casos confirmados SRAG

Bairros do Recife	Casos	Bairros do Recife	Casos	Bairros do Recife	Casos
AFLITOS	43	CORREGO DO JENIPAPO	50	NOVA DESCOBERTA	210
AFOGADOS	198	CURADO	79	PAISSANDU	14
ÁGUA FRIA	288	DERBY	25	PARNAMIRIM	63
ALTO DO MANDU	31	DOIS IRMAOS	23	PASSARINHO	84
ALTO JOSE BONIFACIO	68	DOIS UNIDOS	207	PAU FERRO	1
ALTO JOSE DO PINHO	69	ENCRUZILHADA	116	PEIXINHOS	10
ALTO SANTA TERESINHA	35	ENGENHO DO MEIO	67	PINA	175
APIPUCOS	39	ESPINHEIRO	106	POCO	35
AREIAS	207	ESTANCIA	62	PONTO DE PARADA	11
ARRUDA	106	FUNDAO	46	PORTO DA MADEIRA	45
BARRO	115	GRACAS	144	PRADO	79
BEBERIBE	64	GUABIRABA	32	RECIFE	5
BOA VIAGEM	957	HIPODROMO	19	ROSARINHO	77
BOA VISTA	158	IBURA	379	SAN MARTIN	184
BOMBA DO HEMETERIO	63	ILHA DO LEITE	24	SANCHO	70
BONGI	75	ILHA DO RETIRO	34	SANTANA	26
BRASILIA TEIMOSA	108	ILHA JOANA BEZERRA	74	SANTO AMARO	216
BREJO DA GUABIRABA	57	IMBIRIBEIRA	302	SANTO ANTONIO	20
BREJO DE BEBERIBE	27	IPSEP	168	SAO JOSE	55
CABANGA	8	IPUTINGA	337	SITIO DOS PINTOS	24
CACOTE	26	JAQUEIRA	24	SOLEDADE	13
CAJUEIRO	54	JARDIM SAO PAULO	199	TAMARINEIRA	124
CAMPINA DO BARRETO	65	JIQUIA	43	TEJIPIO	83
CAMPO GRANDE	196	JORDAO	138	TORRE	154
CASA AMARELA	274	LINHA DO TIRO	83	TORREAO	15
CASA FORTE	89	MACAXEIRA	100	TORROES	194
CAXANGA	69	MADALENA	241	TOTO	32
CIDADE UNIVERSITARIA	13	MANGABEIRA	32	VARZEA	429
COELHOS	94	MANGUEIRA	57	VASCO DA GAMA	194
COHAB	366	MONTEIRO	23	ZUMBI	44
COQUEIRAL	51	MORRO DA CONCEICAO	43	-	-
CORDEIRO	260	MUSTARDINHA	66	-	-

Fonte: Secretaria de Saúde de Pernambuco – SES-PE

3.3 GERAÇÃO DOS *CLUSTERS* E DADOS ESTATÍSTICOS

O software utilizado para o desenvolvimento da estatística de varredura espaço-temporal foi o SaTScan.

As análises foram baseadas em metodologia estatística de varredura espaço-temporal, com base em uma janela cilíndrica com uma base geográfica circular (ou

elíptica), e com a altura correspondente ao tempo, a qual é movida no espaço e no tempo, de modo que para cada localidade e dimensão geográfica, também visita cada período de tempo possível.

O modelo estatístico utilizado na indicação dos *clusters* dos bairros mais afetados pela SRAG da contaminação do COVID-19, foi o modelo discreto de Poisson, com a utilização da estatística de varredura espaço-temporal, coordenadas geográficas dos centroides dos bairros do Recife e dos dados de casos confirmados SRAG e da população.

Segundo Kulldorff (2015), a análise de variação espacial nas tendências temporais só pode ser realizada usando o modelo discreto de Poisson; e quando a hipótese for nula, e quando não existem covariáveis, o número esperado de casos em cada área é proporcional ao tamanho de sua população, ou das pessoas-ano nessa área.

Esse modelo não é aleatório, sendo definido por malha de pontos de localidade – regular ou irregular - com localidade fixas, e é avaliado a aleatoriedade espacial da observação condicionando à malha. Por isso, todas essas são versões do que se denomina de estatísticas de varredura discretas (HENRY et al., 2009).

O tempo utilizado no presente estudo foi o ano de 2020 até o ano de 2021. Os dados da população dos bairros foram adquiridos pelo censo do IBGE, 2010. Os dados de população são necessários apenas em pontos selecionados do tempo, e os números são interpolados nos intervalos entre eles.

Os dados utilizados no software foram em formatos *shapefile* e escolhidas os parâmetros e análise a ser realizados. O tipo de análise escolhida foi a *Space-Time*, com modelo de probabilidade de Poisson e varredura para áreas com alta taxas.

No que diz respeito as janelas espaciais para uma análise mais avançada, foi utilizado limite de 50% do percentual da população de risco. Esses *clusters* devem ser gerados com *P-value* abaixo de 0,05, o qual é considerado significativo (KULLDORFF, 2018).

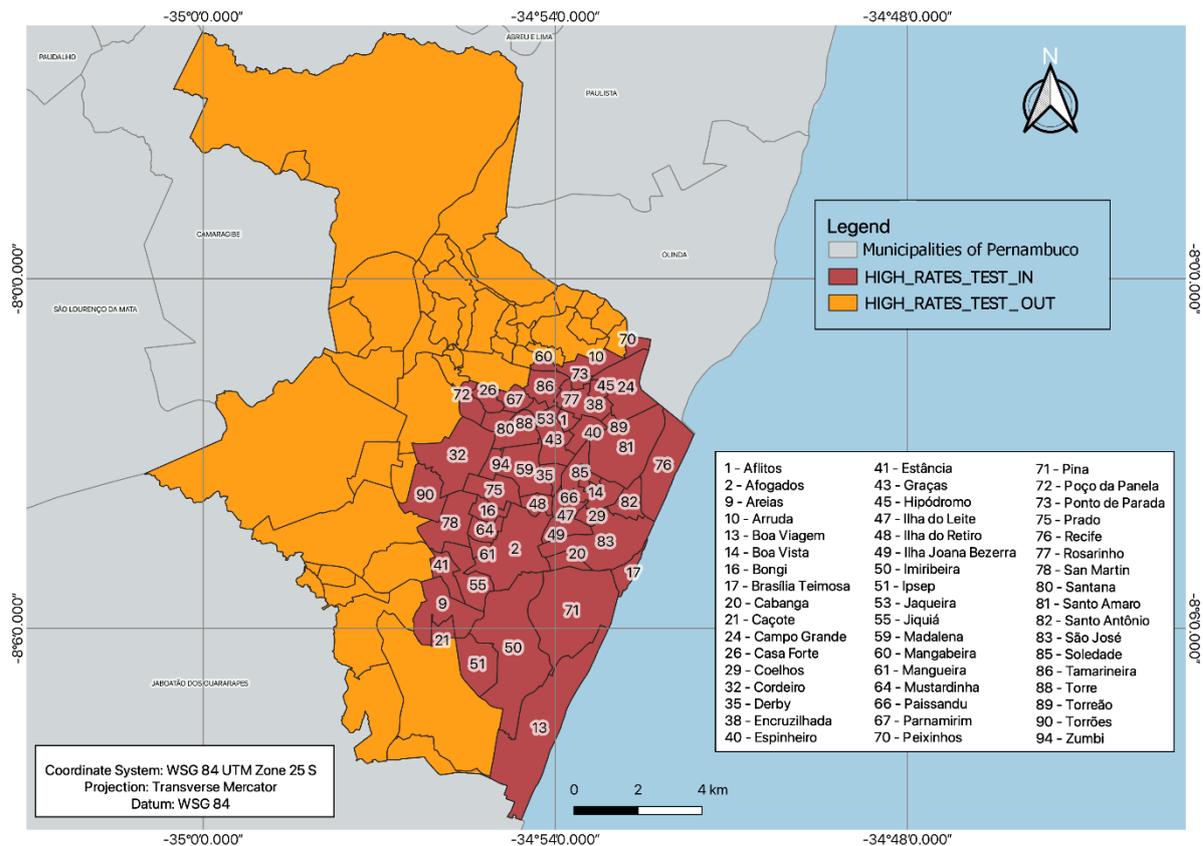
No que diz respeito a replicações de Monte Carlo para execução de análise real, foi definido o valor de 999 inferências para realização de testes, o qual é considerado padrão para cálculo e obtenção de significância dos resultados (XU et. al., 2021). De acordo com Kulldorff (2014) e Kumar (2014) “um número maior é sempre melhor do ponto de vista estatístico, pois aumentará o poder estatístico da análise. Acima de 999, o aumento de poder é muito marginal. A desvantagem de um número maior é que a análise leva mais tempo para ser executada”.

Assim, foi calculada a razão de Log-verossimilhança (LLR – Log Likelihood Radio), a qual é a significância estatística testada por simulações de Monte Carlo (Kulldorff, 2018). O LLR é calculado e uma distribuição é obtida. Se o *cluster* potencial tiver um LLR superior do que, por exemplo, 95% dos conjuntos de dados gerados sob a nula hipótese, o *cluster* é considerado estatisticamente significativo a 0,05 nível de confiança. A zona com o valor LLR máximo e com a significância estatística é considerada o *cluster* mais provável, ou seja, o *cluster* com menos probabilidade de ter ocorrido por acaso (XU, 2021).

4. RESULTADOS E DISCUSSÕES

Os potenciais aglomerados espaciais de casos COVID-19 com altas taxas de Síndrome Respiratória Aguda Grave – SRAG (HIGH_RATES_TEST_IN) por bairro na cidade do Recife foram detectados e estão apresentados de acordo com a Figura 2.

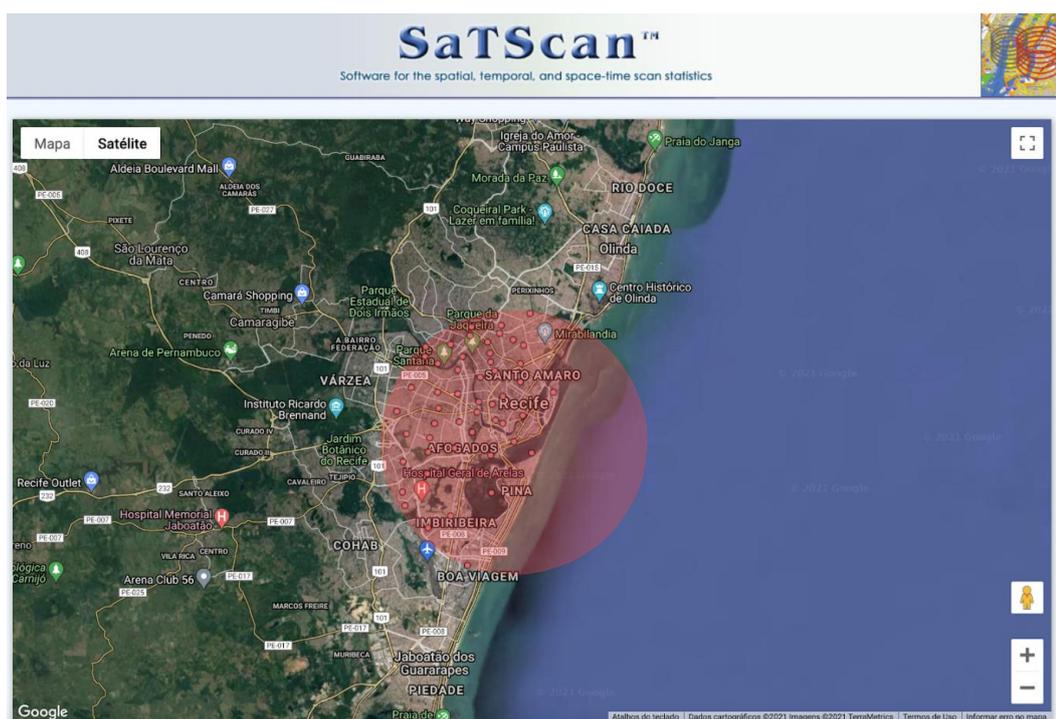
Figura 2: Aglomerados espaciais dentro e fora da zona de alto potencial



Fonte: Autor

Foi encontrado um *cluster* relativo a 51 bairros. Como apresentado na Figura 3.

Figura 3: *Cluster* e bairros identificados



Fonte: Autor

A Tabela 2, a seguir, e refere-se aos resultados do *cluster* detectado.

Tabela 2: Resumo dos dados SaTScan

<i>Clusters</i> Detectados	
Coordenadas / raio	(8.074523 S, 34,886913 W) / 6.25 km
População	765051
Número de casos SRAG	5576
Casos esperados	2576,38
Casos anuais / 100000	727,3
Observados / esperados	2,16
Risco relativo	3,54
Log-verossimilhança	1982,502966
P-value	<0.000000000000000001

Fonte: Autor

A população referente ao *cluster* potencial é equivalente a um total de 765.051. O número de casos confirmados SRAG nesses bairros totaliza 5.576 e tem 2.576,38 casos esperados para esse *cluster*.

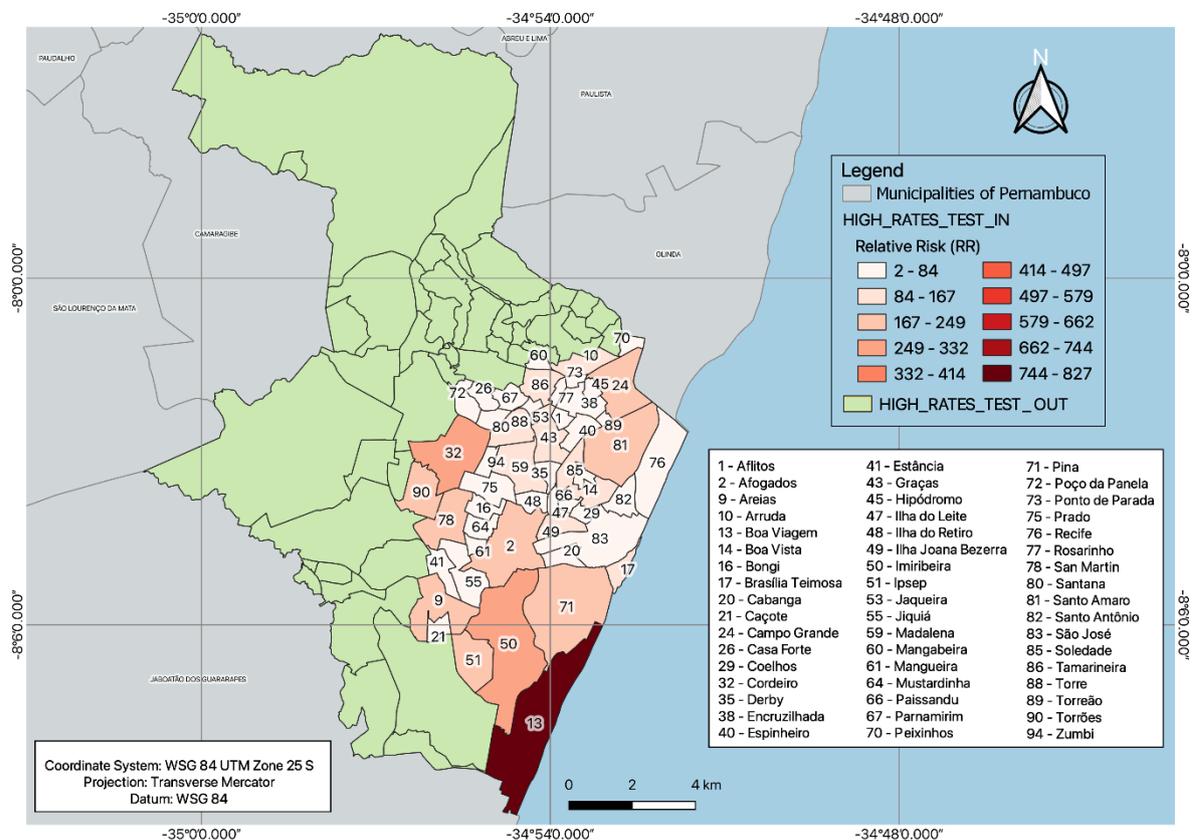
O coeficiente de incidência anual por 100 mil habitantes, corresponde ao valor de 727,3. Os casos observados pelos esperados estão relacionados a estatística qui-quadrado de verossimilhança e é baseado na razão das frequências observadas para as esperadas, ou seja, é definido para saber se as variáveis estão associadas. Então quanto menor o valor, melhores serão as chances de nossa hipótese ser verdadeira.

No que diz respeito ao risco relativo (RR), o qual é uma medida da força da associação entre o fator de risco e a ocorrência do agravo (PEREIRA, 2004) e corresponde ao valor de 3,54.

O RR varia em uma escala de 0 a 1, e quando maior do que 1, a associação sugere que o fator estudado seria um fator de risco; quanto maior o RR, maior a força da associação entre exposição e o efeito estudado (SELIGMAN, 2006). Ou seja, significa que a população que se encontra no *cluster* de alta taxa SRAG possui 3,54 vezes mais chance de ter a síndrome (HIGH_RATES_TEST_IN) do que os que não estão dentro do *cluster* (HIGH_RATES_TEST_OUT).

Ainda com relação ao risco relativo, foi elaborado o mapa para identificar os bairros com maior chance de se ter a SRAG dentro do *cluster* gerado (Figura 4).

Figura 4: Mapa de Risco Relativo (RR) dos bairros dentro do *cluster*



Fonte: Autor

Observa-se que o bairro com ID 13 (Boa viagem) possui maior risco da população contrair a Síndrome Respiratória Aguda Grave, seguido dos bairros de ID 32 (Cordeiro) e ID 50 (Imbiribeira).

Com relação ao log da verossimilhança, a determinação dos valores ideais dos coeficientes estimados (β), a maximização da probabilidade de log foi alta com valor aproximado de 1982,5, significando dizer que o modelo oferece um bom ajuste dos dados.

O P-value inferior a 0,0000000000000001 refere-se a uma evidência muito forte contra H_0 , ou seja, tendo o nível de significância (α) 0,05 como utilizado, o P-value menor do que α a hipótese nula foi rejeitada, e isso significa dizer que a distribuição da epidemia não é aleatória (hipótese nula rejeitada), estando relacionada a conglomerados de alto risco ou incidência.

4. CONCLUSÕES E CONSIDERAÇÕES FINAIS

Os potenciais *clusters* espaciais são importantes para serem alvos nas intervenções governamentais para mitigar uma maior propagação. A presença de *clusters* de COVID-19 em nível de bairro na cidade do Recife no período de estudo fornece pistas para os formuladores de políticas para melhor projetar e implementar as medidas de controle a nível local.

Com conhecimento do *cluster* mais prováveis mostrando a tendência de se mover do leste da cidade para oeste, teria a possibilidade de intervir preventivamente. A análise também fornece uma boa compreensão do padrão dos agrupamentos espaciais de COVID-19.

Sugere-se que os bairros pertencentes a aglomerados emergentes devem ser priorizados ao alocar recursos e implementar várias medidas de quarentena e isolamento para retardar a transmissão viral. O COVID-19 e a vigilância geral de doenças infecciosas podem se beneficiar da abordagem prospectiva monitorando surtos à medida que novos dados se tornam disponíveis.

Também é sugerido o desenvolvimento de estudos mais específicos para verificar se parâmetros complementares como renda familiar, acesso a água e esgotamento sanitário, faixa etária, dentre outros, possuem relação com os *clusters* da SRAG.

Enfatizo a importância de focar a vigilância em aglomerados emergentes e ativos durante epidemias, essencialmente descartando grupos anteriores que não ameaçam a saúde pública que apareceriam em uma análise retrospectiva.

REFERÊNCIAS BIBLIOGRÁFICAS

BASTOS, F.I.; BARCELLOS, C. Are geoprocessing, environment, and health a possible combination? **Cad. Saúde Pública**. 1996. Rio de Janeiro, v. 12, n. 3.

CARDOSO, P.V. SEABRA, V.S. BASTOS, I.B. COSTA, E.C.P. A importância da análise espacial para tomada de decisão: um olhar sobre a pandemia de COVID-19. **Revista Tamoios**, 2020. v. 16, n.1, p. 125-137.

COSTA, M.A. ASSUNÇÃO, R.M. Uma análise de desempenho dos métodos SCAN e BESAG&NEWELL na detecção de conglomerados espaciais. In: Simpósio Brasileiro de Geoinformática, 2006, Campos do Jordão, SP. **Anais do Simpósio Brasileiro de Geoinformática**. Campos do Jordão, SP: Instituto Nacional de Pesquisas Espaciais – INPE, 2006.

DRUCK, S. CARVALHO, M.S. CAMARA, G. MONTEIRO, A.V.M. Análise espacial de dados geográficos. (Ed.). 2004. Brasília. EMBRAPA (ISBN: 85-7383-260-6).

ELLIOTT P, WARTENBERG D. Spatial epidemiology: current approaches and future challenges. **Environmental Health Perspectives**. 2004. v. 112, n. 9, p. 998-1006.

FERREIRA, R.V. MARTINES, R.H. TOPPA, L.M. ASSUNÇÃO, L.M.. DESJARDINS, M.R. DELMELLE, E.M. Applying a Prospective Space-Time Scan Statistic to Examine the Evolution of COVID-19 Clusters in the State of São Paulo, Brazil, **medRxiv**. 2020. v. 1.

GIAVONI, A. TAMAYO, A. Análise espacial: conceito, método e aplicabilidade. **Psicologia: Reflexão e Crítica**, 2003. v. 16, n. 2, p 303-307.

HENRY, K.A. NIU, X. BOSCOE, F.P. Geographic disparities in colorectal cancer survival. **International Journal of Health Geographics**. 2009. v, 8. n, 48.

IBGE. INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. Panorama dos Municípios. Disponível em: <https://cidades.ibge.gov.br/brasil/pe/recife/panorama>. Acesso em: nov 2021.

KULLDORFF, M. Prospective time periodic geographical disease surveillance using a scan statistic. 2001. **J. R. Stat. Soc.** v. 164, n. 1, p 61–72.

KULLDORFF, M. SaTScan™ manual do usuário. 2015. v, 9.4. p. 19. Disponível em: https://www.satscan.org/SaTScan_TM_Manual_do_Usu%C3%A1rio_v9.4_Portugues.pdf Acesso em: 26 nov. 2021.

KULLDORFF M. SaTScan™ software for spatial, temporal and space-time scan statistics. User guide space-time scan statistics. 2018. Disponível em: <: <https://www.satscan.org/>>. Acesso em: 7 dez. 2021.

- LANDIM, P.M.B. Sobre geoestatística e mapas. **Terrae Didática**. 2006. v.2, n. 1. p. 19-33
- LANDIM, P.M.B. Sobre geoestatística e mapas. **Terrae Didática**. 2006. v.2, n. 1. p. 22
- LAWSON, A. BIGGERI, A. BÖHNING, D. LESAFFRE, E. VIEL, J.F. BERTOLLINI, R. Disease mapping and risk assessment for public health. 1999. (Ed.). Wiley, Chichester. 482 p. ISBN (0-47198634-8).
- MEDRONHO, R.A. Avaliação do método geoestatístico no estudo da distribuição espacial da hepatite A. 1999. 90 f. Tese (Doutorado em Saúde Pública) – Escola Nacional de Saúde Pública, Fiocruz, Rio de Janeiro, 1999.
- PEREIRA, S.D. Conceitos e definições da saúde e epidemiologia usados na vigilância sanitária. Centro de Vigilância Sanitária. São Paulo. 2004. p 1 – 33. Disponível em: <http://www.cvs.saude.sp.gov.br/pdf/epid_visu.pdf> Acesso em: 30 nov. 2021.
- RUSHTON G. Public health, GIS, and spatial analytic tools. *Annu Rev Public Health*. 2003. v. 24, p. 43-56.
- SELIGMAN, L.C. DUNCAN, B.B. BRANCHTEIN, L. GAIO, D.S. MENGUE, S.S. SCHMIDT, M.I. Obesity and gestational weight gain: cesarean delivery and labor complications. *Revista de Saúde Pública*. 2006. v. 40, n. 3. p 457-465.
- SOUZA, E.C.O. SANTOS, E.S. ROSA, A.M. BOTELHO, C. Varredura espaço-temporal para identificação de áreas de risco para hospitalização de crianças por asma em Mato Grosso. **Revista Brasileira de Epidemiologia**, 2019. v. 7, n. 1, p. 5.
- STURARO, J.R. Geoestatística básica. 2015. São Paulo. Universidade Estadual Paulista (Apostila de Geoestatística Básica).
- XU, F. BEARD, K. A comparison of prospective space-time statistics and spatiotemporal event sequence based clustering for COVID-19 surveillance. **Journals Plos One**. 2021. v. 10. p 1 – 23.